基于深度 BLSTM-LSTM 网络模型的阿尔兹海默症判别

李泓蓓

（北京化工大学信息学院 北京 10010）

摘要

随着科学技术的发展，脑电信号因为蕴含丰富的生理、心理和病理内容，而被运用与越来越多的领域。经过在脑电信号的数据集上的相关实验表明，本项目实现的基于使用基于 BLSTM 和 LSTM 模型对阿尔兹海默症的判别取得了较好的结果，平均准确率为 93%左右。

关键词：脑电信号，阿尔兹海默症，长短时记忆网络

1 研究背景

阿尔兹海默症(Alzheimer's disease）是一种常出现于老年群体中的神经性脑疾病，是全球第四大死亡原因。其通常以记忆渐进性丧失和认知功能退化为特征，患者逐渐从正常老年人转变为轻度认知障碍，随着患病时间神经元及其连接被逐渐破坏，导致认知功能丧失，最终成为老年痴呆。我国 2019 年的报告显示，我国中老年群体中大约有 6%的人患有老年痴呆，1000 万人以上正在经受着疾病带来的痛苦。[1]

阿尔兹海默症病症情况较多且复杂，诊断需要大量的检查，而具备全套早期诊断的医院寥寥无几，加上病理检查费用高昂等多重原因，使得阿尔兹海默症诊断技术和手段上亦面临难题。此外我国老年人群体所占社会比例日益增加，加之人民群众“看病难”这一问题还未完全解决，我国现有的医疗卫生资源配置不合理，偏远贫困地区享有的医疗资源相比于一线城市少之又少。正因如此，我国的阿尔兹海默症患者在诊断时超过半数的人都已经是中重度患者。而阿尔兹海默症越早治疗治愈的可能性就越高，因此如何早期诊断出阿尔兹海默症具有重要研究意义。[2]

脑电图（Electroencephalogram，EEG）信号是通过在头皮上放置电极或佩戴电极帽，用于记录脑细胞群的自发性、节律性电活动的技术方法。被广泛用作临床科研,用以检测和鉴别多种脑部病变和识别大脑疾病，它是神经科医生和临床专家诊断癫痫、睡眠障碍、精神分裂症、预测癫痫发作、抑郁症、等的主要工具之一[3]。

综上，本文将基于以上背景，通过使用脑电信号数据，结合深度学习模型实现阿尔兹海默症的诊断。

2 相关技术

长短期记忆网络（LSTM，Long Short-Term Memory，LSTM）是一种时间循环神经网络，是为了解决一般的 RNN（循环神经网络）存在的长期依赖问题而专门设计出来的，所有的 RNN 都具有一种重复神经网络模块的链式形式。在标准 RNN 中，这个重复的结构模块只有一个非常简单的结构，例如一个 tanh 层。

由于梯度爆炸和梯度消失现象的存在，简单循环神经网络模型误差处理长距离序列数据。为了解决误差不能长距离反向传播的问题。1997 年，Sepp Hochreiter 和 Jürgen Schmidhuber 提出了一种改进的循环神经网络，称为长短时记忆网络[4]。这种神经网络最大的特点是可以免简单循环神经网络梯度消失问题，因此在工业界得到了广泛的应用。

在单向的循环神经网络中，模型实际上只使用到了“上文”的信息，而没有考虑到“下文”的信息。在实际场景中，预测可能需要使用到整个输入序列的信息。因此，目前业内主流使用的都是双向的循环神经网络。顾名思义，双向循环神经网络结合了序列起点移动的一个循环神经网络和令一个从序列末尾向序列起点移动的循环神经网络。而作为循环神经网络的一种拓展，LSTM 自然也可以结合一个逆向的序列，组成双向长短时记忆网络(Bi-directional Long Short-Term Memory, Bi-LSTM)，是由前向 LSTM 与后向 LSTM 组合而成。这个想法是将负责正时间方向（正向状态）的部分和负时间方向的一部分（后向状态）分割成正常 RNN 的状态神经元，对于 LSTM 的递归神经网络有重大影响。

下图展示了一个双向 LSTM 的结构图:

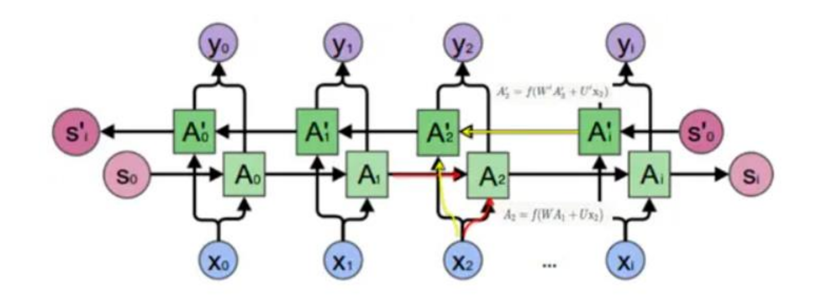


图 1 一个双向 LSTM 的结构图

LSTM 网络模型结构描述如下：

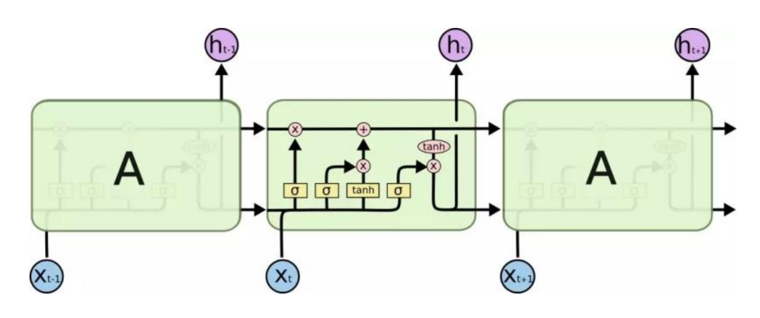


图 2 LSTM 的网络模型结构图

核心的内容是如何来控制单元状态 c_t 信息的输入和输出。LSTM 采用三个控制开关或门来决定单元状态的改变。可以将上述 t 时刻的隐藏层简化为如下的示意图。图中可以看出有三个开关，或称为“门”来控制中间的单元状态 c_t，左侧的为遗忘门，用来控制上一个时刻的单元状态 c_{t-1} 继续在 t 时刻保留；下面的为输入门，控制当前时刻的输入到长期状态的信息。右边的为输出门，控制当前时刻 t 单元状态的输出信息。

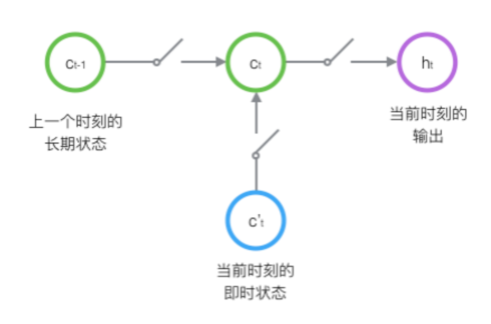


图 3 LSTM 模型简化示意图

所谓“门”，在算法的实现上实际是一个全连接层。如下图所示，x 是输入向量，W 是门的权重，σ 为激活函数。

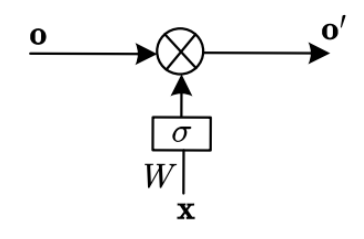


图 4 门的结构示意图

上图中，门可以表示为：

$$g(x) = \sigma(Wx + b)$$

LSTM 单元内部运算分为三个阶段:遗忘、记忆和输出。遗忘阶段使用遗忘门对内部状态加权,实现对长期记忆的遗忘;记忆阶段对输入进行特征提取,同时使用输入门将重要特征保存至内部状态中,完成长期记忆的更新;输出阶段使用输出门从内部状态中挑选输出信息。

3 基于 LSTM 的模型架构

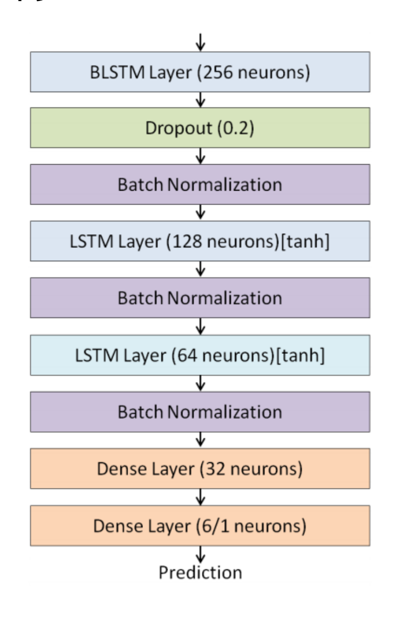


图 5　Deep BLSTM-LSTM 模型架构

长短时记忆网络具备发现序列数据中潜在时序依赖关系的能力，因此，本文参考了[5]所提出的 Deep BLSTM-LSTM 模型的架构,大致由 9 层构成，具有一个 BLSTM 和两个 LSTM 层，以及 Dropout、批量归一化和全连接层。

输入信号首先进入由 256 个神经元组成的 Bi-LSTM 层，然后经过 Dropout 层。接下来，执行批量归一化，将结果馈送到包含 128 个隐藏神经元的 LSTM 层。

然后应用另一个批量归一化层，该层之后是另一个具有 64 个隐藏神经元的 LSTM 层和另一个归一化层。最后依次进入两个全连接层。

该模型以端到端的方式对原始脑电信号进行如下处理：

（1)**形态特征提取**,通过提取正常与阿尔兹海默症患者脑电信号中的特征，进行学习。本文通过双向 LSTM 神经网络提取挖掘脑电信号中的形态特性。此外，在 Bi-LSTM 后加入一个 Dropout 层防止过拟合现象。

（2）**特征增强**，利用 LSTM 学习信号样本间的时序依赖关系，强化特征。经过 LSTM 层后转化为含有信号特性和时序依赖关系的组合，在 Dense 层中深化特征并调整尺寸。

4 实现步骤

4.1 数据预处理

在所使用的数据集中，每一个文件格式为 1024 x 19，数据的数量比较少。为了扩充数据集以及后续模型更好的处理数据，在数据预处理阶段对数据进行裁剪，将其分割为 32 x 19 的大小，并按一定的编号顺序存储为新的 txt 文件。

此外，本阶段中为不同类型的文件设计了标签，健康 标记为‘0’，患者 标记为 ‘1’,并将标签保存至 txt 文件中。

4.2 数据封装

将预处理后的数据，封装为一个类，继承于 Dataset，重写其中的函数,便于后续读取、加载数据等操作。编写 load_mydata 函数，便于加载数据集。

4.3 数据分类

关于数据分类和加载：

将全部数据读入，加载中打乱顺序。按照一定比例将数据划分为训练集以及测试集。（train、test）

在存放文件名与标签对应关系的 txt 文件中，按照与相同比例，划分测试集和训练集的存放文件名与标签对应关系为两个 txt 文件。

4.4 训练和测试

训练按照通用四步走策略开展：

（1）计算当前网络权重下的正向输出结果和实际结果的损失；

（2）梯度置 0，防止梯度累计；

（3）反向传播；

（4）梯度下降，执行一步参数更新。采用一轮训练，一轮测试的方式。

5 实验结果及分析

5.1 数据集

数据集选用基于脑电图诊断阿尔茨海默病的分位数图。该数据集由 Dennis Duke 博士和佛罗里达州立大学的其他研究人员共同设计，使用 Biologic Systems Brain Atlas III Plus 工作站从国际 10-20 系统的 19 个头皮位点记录下来。组 A 和 B 代表对照组，由 24 名健康的老年人组成，所有的神经或精神疾病均呈阴性。C 组和 D 组由 24 名可能的阿尔兹海默症患者组成，这些患者通过国家神经和交流障碍和中风研究所和阿尔茨海默病及相关疾病协会 (NINCDS-ADRDA) 以及精神障碍诊断和统计手册 (DSM)-III- 诊断出 R 标准。

5.2 评估指标

准确率：
对于给定的测试数据集，分类模型中所有预测正确的样本数/总观测值的样本数。在代码实现中，对完全匹配的预测样本，进行计数，除以全部的样本数。

5.3 超参数优化

超参数的设置是为了更好的学习数据的结构，保证模型不出现过拟合等现象。超参数是控制模型结构、效率、性能等的重要按钮，可以调节学习率、迭代次数、隐层数目、激活函数、优化器等等。

1.学习率优化

首先对不同初始学习率进行比较。在学习率分别为 0.1、0.01、0.001 下开展实验。如图所示，在学习率为 0.01 时，曲线变化更加平滑，能得到效果更好的模型。

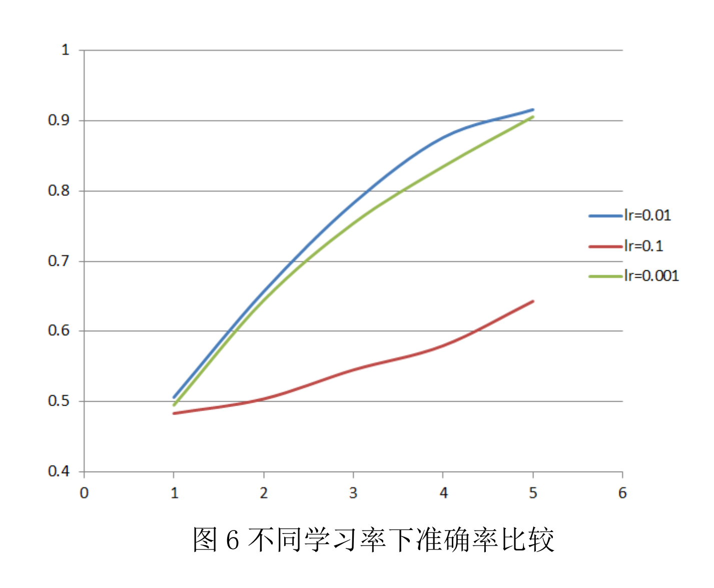


图 6 不同学习率下准确率比较

2. 优化器选择

- 随机梯度下降 SGD ，每次选择一个 mini-batch，而不是全部样本，使用梯度下降来更新模型参数。它解决了随机小批量样本的问题，但仍然有自适应学习率、容易卡在梯度较小点等问题。
- 自适应梯度下降，AdaGrad，是梯度下降优化算法的扩展。AdaGrad 是一种具有自适应学习率的梯度下降优化方法。它使参数的学习率自适应，非常适合处理稀疏数据，可大大提高 SGD 的鲁棒性。
- Adam 优化器，结合 AdaGrad 和 RMSProp 两种优化算法的优点，参数的更新不受梯度的伸缩变换影响，超参数具有很好的解释性，且通常无需调整或仅需很少的微调。

选择了以上三种优化器在数据集中进行相同迭代周期的实验，结果如下表所示。

表 1 不同优化器下的比较

	训练集损失	测试集损失	测试集准确率
SGD	0.427	0.506	0.761
AdaGrad	0.163	0.269	0.895
Adam	0.134	0.236	0.916

根据表中数据可知，Adam 优化器在相同迭代周期内比 SGD 和 AdaGrad 优化器损失率下降速度更快，准确率更高。

5.4 实验结果

基于 5.3 对模型超参数的优化后，调整模型，设置学习率为 0.01，开展训练测试。图 7 展示了训练和测试集的损失值随周期的变化关系。损失值随着训练周期的深入，均呈现了下降趋势。

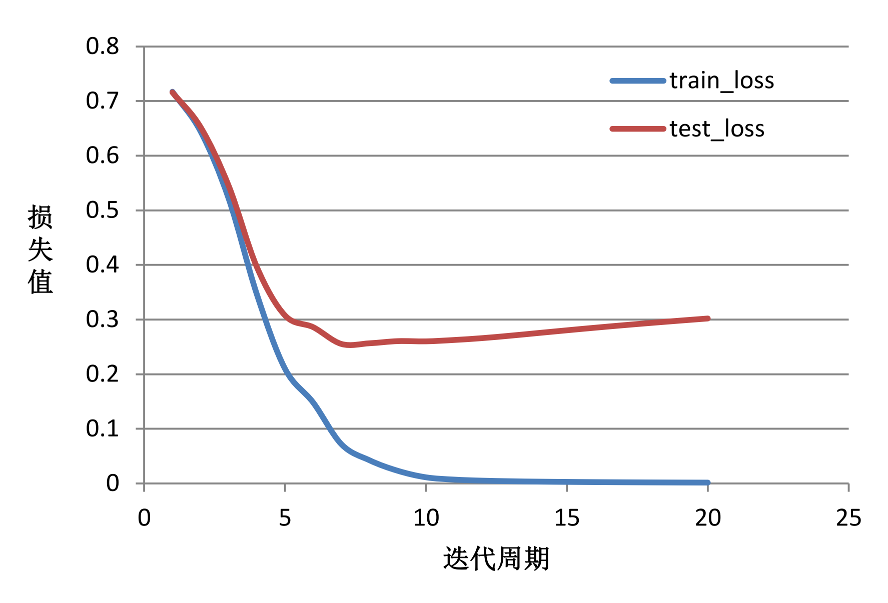


图 7 训练和测试阶段损失值随周期变化图

图 8 显示了训练 20 个周期的损失值和准确率变化，从结果绘制的图像来看，准确率趋近于 1，损失值逐渐收敛。

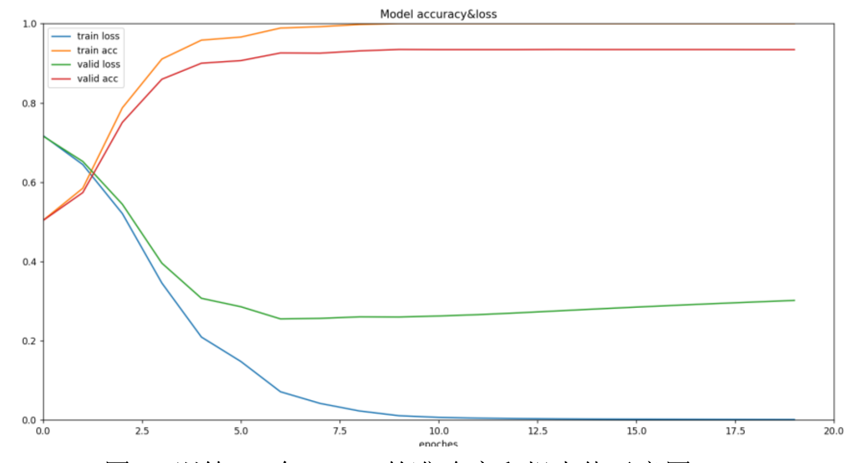


图 8 训练 20 个 epoch 的准确度和损失值示意图

6 总结

随着科学技术的发展，脑电信号因为蕴含丰富的生理、心理和病理内容，而被运用与越来越多的领域。

经过在脑电信号的数据集上的相关实验表明，本项目实现的基于使用深度 BLSTM-LSTM 模型对阿尔兹海默症的判别取得了较好的结果，平均准确率为 93% 左右，说明脑电信号或许可以辅助阿尔兹海默症的判别。本项目数据与代码可在 https://gitcode.net/lhb_taylor/bilstm-lstm 中找到。

从绘制的曲线图，可以看出，在测试集中，存在轻微过拟合的问题，尝试增加 Dropout 层等操作后，没有明显改善。希望后续有时间可以继续探寻解决方案。与传统的机器学习方法相比，深度学习对海量训练数据的依赖性非常强，因为它需要大量的数据来理解数据的潜在模式。本项目使用的数据集较小，虽然对数据进行了分割处理来扩充样本，但数据量偏少，考虑使用 few-shot 以及迁移学习来优化模型，关于如何提高训练的效率、如何改进网络模型等仍然需要进一步研究实验。

参考文献

[1] 孙晓驰. 机器学习方法在阿尔兹海默症诊断中的应用[D].中南财经政法大学,2023.DOI:10.27660/d.cnki.gzczu.2021.002053.
[2] 张帆. 基于多特征融合的超网络功能磁共振影像阿尔兹海默症分类研究[D].太原理工大学,2018.
[3] Sanei S, Chambers J A. EEG signal processing[M]. John Wiley & Sons, 2013:22-29.
[4] Hochreiter S , Schmidhuber J .Long Short-Term Memory[J].Neural Computation, 1997, 9(8):1735-1780.DOI:10.1162/neco.1997.9.8.1735.
[5] P. Kaushik, A. Gupta, P. P. Roy and D. P. Dogra. EEG-Based Age and Gender Prediction Using Deep BLSTM-LSTM Network Model[J]. IEEE Sensors Journal,2019,(17)7: 2634-2641.DOI: 10.1109/JSEN.2018.2885582.